



Komputerowa analiza danych doświadczalnych


Wykład 10

28.04.2017

dr inż. Łukasz Graczykowski

lgraczyk@if.pw.edu.pl

Semestr letni 2016/2017



Metoda największej wiarygodności - przykład

Nierówność informacyjna

Przykłady funkcji wiarygodności i prawo kombinacji niepewności

Własności asymptotyczne



Metoda największej wiarygodności (Maximum likelihood method)

Funkcja wiarygodności

- **Funkcją wiarygodności** nazywamy iloczyn postaci:

$$L = \prod_{j=1}^N f(\mathbf{X}^{(j)}; \boldsymbol{\lambda})$$

$$l = \ln L = \sum_{j=1}^N \ln f(\mathbf{X}^{(j)}; \boldsymbol{\lambda}) = \sum_{j=1}^N \frac{f'(\mathbf{X}^{(j)}; \boldsymbol{\lambda})}{f(\mathbf{X}^{(j)}; \boldsymbol{\lambda})}$$

- Funkcja wiarygodności **jest zmienną losową** (jest funkcją próby)
- **Największą ufnością** obdarzamy zbiór parametrów, dla którego funkcja wiarygodności osiąga **maksymalną wartość**

- **Jak wyznaczyć maksimum?**

– warunek konieczny: przyrównać pierwszą pochodną L do zera

- Różniczkowanie iloczynu jest jednak niewygodne, wprowadzamy więc **logarytm funkcji wiarygodności** l :

$$l = \ln L = \sum_{j=1}^N \ln f(\mathbf{X}^{(j)}; \boldsymbol{\lambda})$$

- **Funkcją wiarygodności** jest odpowiednikiem gęstości prawdopodobieństwa, tylko określona dla parametrów. Ponieważ jest funkcją próby losowej, jest również zmienną losową

- Równania wiarygodności: $\frac{\partial l}{\partial \lambda_i} = 0, \quad i=1, 2, \dots, p$

Przykład - estymacja param. rozkładu norm.

- **Przykład:** badamy rozkład wagi studentek amerykańskich college'ów
 - rozkład wagi studentek w populacji jest opisany rozkładem normalnym o wartości średniej μ i wariancji σ^2
 - założmy, że wybraliśmy $N=10$ reprezentantów, których wagi (w kg) $X^{(j)}$ układają się następująco:
 - 52,2 55,3 59,0 57,6 67,6 72,6 68,9 62,6 67,6 81,6
 - **Zadanie:** na podstawie wyniku pomiaru znajdź najbardziej wiarygodną estymację parametrów rozkładu
 - oczywiście funkcja rozkładu prawdopodobieństwa każdego wyniku (wagi studentek) dana jest wzorem:

$$f(X^{(j)}; \mu, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} \exp\left(\frac{-(X^{(j)} - \mu)^2}{2\sigma^2}\right)$$

- konstruujemy funkcję wiarygodności:

$$L(\hat{\mu}, \hat{\sigma}) = \sigma^{-n} (2\pi)^{-n/2} \exp\left[-\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (X^{(j)} - \hat{\mu})^2\right]$$

Przykład - estymacja param. rozkładu norm.

- konstruujemy funkcję wiarygodności:

$$L(\hat{\mu}, \hat{\sigma}) = \hat{\sigma}^{-n} (2\pi)^{-n/2} \exp \left[-\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (X^{(j)} - \hat{\mu})^2 \right]$$

- oraz logarytmiczną funkcję wiarygodności:

$$l(\hat{\mu}, \hat{\sigma}) = \ln L(\hat{\mu}, \hat{\sigma}) = \ln \left(\hat{\sigma}^{-N} (2\pi)^{-n/2} \left[-\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (X^{(j)} - \hat{\mu})^2 \right] \right) = -\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (X^{(j)} - \hat{\mu})^2 + const$$

- równania wiarygodności:

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\mu}} = 0 \quad \frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\sigma}} = 0$$

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\mu}} = \frac{-2 \sum_{j=1}^N (X^{(j)} - \hat{\mu})(-1)}{2\hat{\sigma}} = 0 \Rightarrow \sum_{j=1}^N (X^{(j)}) - N\hat{\mu} = 0 \Rightarrow \hat{\mu} = \frac{\sum_{j=1}^N X^{(j)}}{n}$$

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\sigma}} = -\frac{n}{2\hat{\sigma}} + \frac{\sum_{j=1}^N (X^{(j)} - \hat{\mu})}{2\hat{\sigma}^2} = 0 \Rightarrow \hat{\sigma}^2 = \frac{\sum_{j=1}^N (X^{(j)} - \hat{\mu})^2}{n}$$

- dla formalności powinniśmy jeszcze sprawdzić drugie pochodne...

Przykład - estymacja param. rozkładu norm.

- liczymy estymatory:

$$\hat{\mu} = \frac{\sum_{j=1}^n X^{(j)}}{n} = 645/10 = 64,5$$

$$\hat{\sigma}^2 = \frac{\sum_{j=1}^n (X^{(j)} - \hat{\mu})^2}{n} = 714/10 = 71,4$$

- otrzymaliśmy (poprzez metodę największej wiarygodności) estymację parametrów rozkładu normalnego całej populacji na podstawie pomiaru próby
- **Koniec**



Nierówność informacyjna

Nierówność informacyjna

- **Pytanie:** jak skonstruować estymator o optymalnych własnościach?
 - estymator jest nieobciążony, jeżeli **wartość obciążenia dla każdej próby:** $B(\lambda) = E(S) - \lambda = 0$
 - oraz (**estymator zgodny**) **wariancja estymatora jest jak najmniejsza** (dąży do 0 dla liczebności próby losowej dążącej do nieskończoności): $\sigma^2(S)$ - *minimalna*
 - bardzo często istnieje jednak związek pomiędzy obciążeniem a wiarancją i musimy szukać kompromisu – taki związek nazywamy **nierównością informacyjną**
- Po dłuższych przekształceniach (Wykład 9, Brandt) otrzymujemy nierówność informacyjną – związek między obciążeniem, wiarancją i informacją zawartą w próbie:

$$\frac{(B'(\lambda)+1)^2}{I(\lambda)} \leq \sigma^2(S)$$

$$I(\lambda) = E(l'^2) = -E(l'')$$
$$I(\lambda) = E(l'^2) = NE \left(\left(\frac{f'(x^{(j)}; \lambda)}{f(x^{(j)}; \lambda)} \right)^2 \right)$$
$$l' = \sum_{j=1}^N \frac{f'(x^{(j)}; \lambda)}{f(x^{(j)}; \lambda)}$$

Nierówność informacyjna

- **Nierówność informacyjna:**

$$\frac{(B'(\lambda)+1)^2}{I(\lambda)} \leq \sigma^2(S)$$

$$I' = \sum_{j=1}^N \frac{f'(x^{(j)}; \lambda)}{f(x^{(j)}; \lambda)}$$

- **Nierówność informacyjna** to związek pomiędzy obciążeniem, wariancją i informacją zawartą w próbie
- Jest to definicja ogólna. Prawa strona jest dolnym ograniczeniem dla wariancji danego (dowolnego) estymatora – ograniczenie to nazywamy **ograniczeniem minimalnej wariancji** albo **ograniczeniem Cramea-Rao**
- Kiedy obciążenie nie zależy od λ , a w szczególności gdy znika (równa się zero), nierówność redukuje się do:

$$\sigma^2(S) \geq \frac{1}{I(\lambda)}$$

Nierówność informacyjna

- **Możemy teraz zadać pytanie:** jaki jest warunek osiągnięcia minimalnej wariancji? Innymi słowy, kiedy we wzorze Cramea-Rao zachodzi równość?

- Można pokazać (Brandt), że zajdzie tak, gdy: $E(S) = B(\lambda) + \lambda$

$$l' = A(\lambda)(S - E(S)) \quad l = B(\lambda)S + C(\lambda) + D \quad L = d \exp(B(\lambda)S + C(\lambda))$$

- Wtedy w przypadku estymatora nieobciążonego o minimalnej wariancji otrzymujemy:

$$\sigma^2(S) = \frac{1}{I(\lambda)} = \frac{1}{E(l'^2)}$$

$$\sigma^2(S) = \frac{1}{|A(\lambda)|}$$

- Estymatory spełniające powyższe warunki nazywamy **estymatorami o najniższej wariancji**
- Jeżeli zamiast: $L = d \exp(B(\lambda)S + C(\lambda))$ spełniony jest słabszy warunek: $L = g(S; \lambda) c(X^{(1)}, X^{(2)}, \dots, X^{(N)})$
- Wtedy S nazywamy **estymatorem wystarczającym** dla λ



Przykłady funkcji wiarygodności

Przykłady funkcji wiarygodności

- Rozkład Poissona

$$f(k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

- Funkcja wiarygodności

$$l = \sum_{j=1}^N \left\{ k^{(j)} \ln \lambda - \ln(k^{(j)}!) - \lambda \right\}$$

- oraz jej pochodna

$$\frac{dl}{d\lambda} = l' = \sum_{j=1}^N \left\{ \frac{k^{(j)}}{\lambda} - 1 \right\} =$$

$$\frac{1}{\lambda} \sum_{j=1}^N \left\{ k^{(j)} - \lambda \right\} = \frac{N}{\lambda} (\bar{K} - \lambda)$$

- Średnia arytmetyczna z k jest nieobciążonym estymatorem o minimalnej wariancji równej $\frac{\lambda}{N}$

- Rozkład dwumianowy

$$L(k; \lambda) = \binom{n}{k} \lambda^k (1-\lambda)^{n-k}$$

- Stąd:

$$l = \ln L = k \ln \lambda + (n-k) \ln(1-\lambda) + \ln \binom{n}{k}$$

$$l' = \frac{k}{\lambda} - \frac{n-k}{1-\lambda} = \frac{n}{\lambda(1-\lambda)} \left(\frac{k}{n} - \lambda \right)$$

- czyli średnia arytmetyczna k/n jest estymatorem o minimalnej wariancji równej $\lambda(1-\lambda)/n$



Prawo kombinacji niepewności

Prawo kombinacji niepewności

- Powróćmy do problemu z poprzedniego wykładu – wielokrotny pomiar tej samej wielkości z różną dokładnością, lub (równoważnie) problem pobierania próby z rozkładów normalnych o jednakowej wartości średniej λ i różnych, lecz znanych wariancjach σ_j

- Jak pamiętamy, logarytmiczna funkcja wiarygodności i jej pochodna dla takiego przypadku:
$$l = -\frac{1}{2} \sum_{j=1}^N \frac{(X^{(j)} - \lambda)^2}{\sigma_j^2} + const \quad l' = \frac{dl}{d\lambda} = \sum_{j=1}^N \frac{X^{(j)} - \lambda}{\sigma_j^2} = 0$$

- Możemy pochodną przekształcić:

$$l' = \sum_{j=1}^N \frac{X^{(j)}}{\sigma_j^2} - \sum_{j=1}^N \frac{\lambda}{\sigma_j^2} = \sum_{j=1}^N \frac{1}{\sigma_j^2} \left(\frac{\sum_{j=1}^N \frac{X^{(j)}}{\sigma_j^2}}{\sum_{j=1}^N \frac{1}{\sigma_j^2}} - \lambda \right)$$

- I jego rozwiązanie: $S = \tilde{\lambda} = \sum_{j=1}^N \frac{X^{(j)}}{\sigma_j^2} / \sum_{j=1}^N \frac{1}{\sigma_j^2}$

- Estymator S jest nieobciążonym estymatorem wartości średniej λ .

Prawo kombinacji niepewności

- Jeśli teraz porównamy:

$$l' = \sum_{j=1}^N \frac{X^{(j)}}{\sigma_j^2} - \sum_{j=1}^N \frac{\lambda}{\sigma_j^2} = \sum_{j=1}^N \frac{1}{\sigma_j^2} \left(\frac{\sum_{j=1}^N \frac{X^{(j)}}{\sigma_j^2}}{\sum_{j=1}^N \frac{1}{\sigma_j^2}} - \lambda \right) = \boxed{\sum_{j=1}^N \frac{1}{\sigma_j^2}} (\tilde{\lambda} - \lambda)$$

- Ze wzorem:

$$l' = A(\lambda)(S - E(S)) = A(\lambda)(S - B(\lambda) - \lambda)$$

$$\text{dla } S = \tilde{\lambda} \text{ i } B(\lambda) = 0$$

$$l' = \boxed{A(\lambda)} (\tilde{\lambda} - \lambda)$$

- Widzimy, że estymator ten ma również minimalną wariancję. Jaka ona jest? Posłużmy się wzorem:

$$\sigma^2(S) = \frac{1}{|A(\lambda)|}$$

- Czyli: $\sigma^2(\tilde{\lambda}) = \frac{1}{\sum_{j=1}^N \frac{1}{\sigma_j^2}}$

- Wzór ten określamy jako **prawo kombinacji niepewności**, lub (bardziej kolokwialnie) “**uśrednianie niepewności w kwadratach**”

- Analogicznie jak w prawie dodawania niepewności

Prawo kombinacji niepewności

- Możemy zauważyć, że jeżeli wszystkie pomiary mają jednakową dokładność, otrzymamy:

$$\tilde{\lambda} = \bar{X}, \quad \sigma^2(\tilde{\lambda}) = \frac{\sigma^2}{N}$$

- Analogicznie jak na Wykładzie 7, gdy liczyliśmy wartość oczekiwaną i wariancję z próby
- Wniosek: w zależności od potrzeb, możemy stosować podejście zarówno poprzez obliczanie estymatorów, jak i poprzez metodę największej wiarygodności

Estymatory - wartość oczekiwana

- **Wartość średnia** ze wszystkich elementów próby jest zmienną losową (jest funkcją zmiennych losowych). Jej wartość oczekiwana (tej średniej):

$$E(\bar{X}) = \frac{1}{n} (E(X_1) + E(X_2) + \dots + E(X_n)) = E(X) = \hat{x}, \text{ dla każdego } n$$

- Wniosek: **wartość średnia (arytmetyczna) z próby to estymator nieobciążony wartości oczekiwanej** zmiennej X w populacji
- Możemy obliczyć wariancję wartości średniej:

$$\begin{aligned} \sigma^2(\bar{X}) &= E\{\bar{X} - E(\bar{X})\}^2 = E\left\{\left(\frac{X_1 + X_2 + \dots + X_n}{n} - \hat{x}\right)^2\right\} \\ &= \frac{1}{n^2} E\{[(X_1 - \hat{x}) + (X_2 - \hat{x}) + \dots + (X_n - \hat{x})]^2\} \end{aligned}$$

**PRZYPOMNIENIE
WYKŁAD 7**

- Z uwagi na niezależność zmiennych kowariancje między zmiennymi X_i znikają, czyli ostatecznie:

$$\sigma^2(\bar{X}) = \frac{1}{n} \sigma^2(X) \quad \lim_{n \rightarrow \infty} \sigma^2(\bar{X}) = 0$$

- Wniosek: **wartość średnia (arytmetyczna) z próby jest również estymatorem zgodnym wartości oczekiwanej**



Własności asymptotyczne estymatorów i funkcji wiarygodności

Własności asymptotyczne estymatorów i fun.

- Omówimy teraz niektóre własności funkcji wiarygodności i estymatorów największej wiarygodności dla dużych prób, czyli $N \rightarrow \infty$
- Estymator $S = \tilde{\lambda}$ jest zdefiniowany jako rozwiązanie równania wiarygodności:

$$l'(\lambda) = \sum_{j=1}^N \left(\frac{f'(X^{(j)}; \lambda)}{f(X^{(j)}; \lambda)} \right)_{\tilde{\lambda}} = 0$$

- Rozwijamy $l'(\lambda)$ na szereg Taylora wokół punktu $\lambda = \tilde{\lambda}$
- Czyli: $l'(\lambda) = l'(\tilde{\lambda}) + (\lambda - \tilde{\lambda})l''(\tilde{\lambda}) + \dots$
- Pierwszy wyraz z prawej strony znika (z uwagi na r. wiar.), drugą pochodną możemy zaś zapisać jako (w granicy $N \rightarrow \infty$):

$$l''(\tilde{\lambda}) = \sum_{j=1}^N \left(\frac{f'(X^{(j)}; \lambda)}{f(X^{(j)}; \lambda)} \right)'_{\tilde{\lambda}} \Rightarrow l''(\tilde{\lambda}) = NE \left(\left(\frac{f'(X^{(j)}; \lambda)}{f(X^{(j)}; \lambda)} \right)'_{\tilde{\lambda}} \right)$$

- Jeśli teraz posłużymy się wzorem: $I(\lambda) = E(l'^2) = -E(l'')$

Własności asymptotyczne estymatorów i fun.

- W takim przypadku możemy zapisać:

$$l''(\tilde{\lambda}) = E(l''(\tilde{\lambda})) = -E(l'^2(\tilde{\lambda})) = -I(\tilde{\lambda}) = -1/b^2$$

analogicznie do

$$\sigma^2(S) = \frac{1}{|A(\tilde{\lambda})|}$$

stała \rightarrow

$$\sigma^2(S) = \frac{1}{I(\tilde{\lambda})} = \frac{1}{E(l'^2)}$$

- Innymi słowy:** zastąpiliśmy drugą pochodną logarytmicznej funkcji wiarygodności $l''(\tilde{\lambda})$, która jest funkcją próby, liczbą, która zależy jedynie od gęstości f i estymatora $\tilde{\lambda}$

- Czyli nasze rozwinięcie na szereg Taylora (pomijając wyższe wyrazy):

$$l'(\lambda) = (-1/b^2)(\lambda - \tilde{\lambda}) \Rightarrow l(\lambda) = (-1/2b^2)(\lambda - \tilde{\lambda})^2 + c$$

- Stałą c wznaczamy podstawiając: $\lambda = \tilde{\lambda} \Rightarrow c = l(\tilde{\lambda})$

- I ostatecznie dostajemy ($k = \text{const}$):

$$l(\lambda) - l(\tilde{\lambda}) = -\frac{1}{2} \frac{(\lambda - \tilde{\lambda})^2}{b^2} \Rightarrow L(\lambda) = k \exp\left(-\frac{(\lambda - \tilde{\lambda})^2}{2b^2}\right)$$

- Funkcja wiarygodności (dla dużych N) ma więc **rozkład normalny**

Własności asymptotyczne estymatorów i fun.

- Funkcja wiarygodności (dla dużych N) ma więc **rozkład normalny**

$$L(\lambda) = k \exp\left(-\frac{(\lambda - \tilde{\lambda})^2}{2b^2}\right)$$

$$\text{dla } \lambda = \tilde{\lambda}, u(\tilde{\lambda}) = b \quad \lambda = \tilde{\lambda} \pm b$$

$$\text{otrzymujemy } -(l(\lambda) - l(\tilde{\lambda})) = \frac{1}{2}$$

- Ponieważ estymowaliśmy parametr λ mamy więc: $S = \tilde{\lambda}$, $E(S) = \lambda$

- Czyli $\tilde{\lambda}$ jest nieobciążonym estymatorem o minimalnej wariancji wynoszącej:

$$\sigma^2(\tilde{\lambda}) = b^2 = \frac{1}{I(\tilde{\lambda})} = \frac{1}{E(l'^2(\tilde{\lambda}))} = -\frac{1}{E(l''(\tilde{\lambda}))}$$

- Estymator ma wszystkie właściwości (nieobciążony, zgodny, z minimalną wariancją) **jedynie** w granicy $N \rightarrow \infty$
- Taki estymator nazywany jest estymatorem **asymptotycznie nieobciążonym**
- Analogicznie możemy powiedzieć, że funkcja wiarygodności jest **asymptotycznie normalna**

Własności asymptotyczne estymatorów i fun.

- Powiedzieliśmy sobie poprzednio, że funkcja wiarygodności jest miarą prawdopodobieństwa (rozkładem prawdopodobieństwa), ale dla parametrów badanego rozkładu prawd. danej cechy
- Zatem estymację parametru możemy przedstawić jako wynik i niepewność typu A:

$$\lambda = \tilde{\lambda}, \quad u(\lambda) = \sigma(\tilde{\lambda})$$

- Ponieważ funkcja wiarygodności asymptotycznie dąży do rozkładu normalnego, możemy powiedzieć, że wartość prawdziwa estymowanego parametru zawarta jest w przedziale:

$$\tilde{\lambda} - \sigma(\tilde{\lambda}) < \lambda_0 < \tilde{\lambda} + \sigma(\tilde{\lambda})$$

z prawdopodobieństwem 68,3% (“jeden sigma”)

- Podane związki możemy stosować jedynie dla prób o dużym N , dokładność przybliżeń zależy jednak również od rozpatrywanej funkcji gęstości – w każdym przypadku musimy zdecydować, czy powyższa procedura jest uprawniona do zastosowania

Przykład - wyznaczanie średniego czasu życia

- **Przykład:** chcemy zbadać średni czas τ życia jądra jakiegoś izotopu promieniotwórczego
- Prawdopodobieństwo że, istniejące w chwili $t=0$ jądro promieniotwórcze rozpadnie się w przedziale czasu od t do $t+dt$ wynosi:

$$f(t) dt = \frac{1}{\tau} \exp(-t/\tau) dt$$

- Badamy oczywiście pewną próbkę zawierającą wiele jąder – założmy, że zaobserwowaliśmy rozpady w chwilach: t_1, t_2, \dots, t_N
- Konstruujemy zatem odpowiednią funkcję wiarygodności:

$$L(\tau) = \frac{1}{\tau^N} \exp\left(-\frac{1}{\tau} \sum_{i=1}^N t_i\right) = \frac{1}{\tau^N} \exp\left(-\frac{N}{\tau} \bar{t}\right)$$

- Obliczamy logarytm i pierwszą pochodną:

$$l(\tau) = \ln L(\tau) = -\frac{N}{\tau} \bar{t} - N \ln \tau$$

$$l'(\tau) = \frac{N}{\tau} \left(\frac{\bar{t}}{\tau} - 1\right) = \frac{N}{\tau^2} (\bar{t} - \tau)$$

Przykład - wyznaczanie średniego czasu życia

- Porównując to ze wzorem:

$$l' = A(\lambda)(S - E(S)) = A(\lambda)(S - B(\lambda) - \lambda)$$

$$\text{dla } S = \tilde{\lambda} \text{ i } B(\lambda) = 0$$

$$l' = A(\lambda)(\tilde{\lambda} - \lambda)$$

$$l'(\tau) = \frac{N}{\tau} \left(\frac{\bar{t}}{\tau} - 1 \right) = \frac{N}{\tau^2} (\bar{t} - \tau)$$

- Widzimy, że rozwiązaniem o największej wiarygodności jest:

$$\tilde{\tau} = \bar{t} \quad \sigma^2(\tilde{\tau}) = \tau^2 / N \Rightarrow \text{dla } \tau = \tilde{\tau} = \bar{t} \Rightarrow \sigma^2(\tilde{\tau}) = \bar{t} / N \quad \sigma^2(\tilde{\lambda}) = \frac{1}{\sum_{j=1}^N \frac{1}{\sigma_j^2}} = \frac{\sigma^2}{N}$$

- Wstawiając $\tau = \tilde{\tau} = \bar{t}$ do wzoru na l otrzymamy:

$$l(\tilde{\tau}) = l_{max} = -N(1 + \ln \bar{t})$$

- Czyli:

$$-(l(\tau) - l(\tilde{\tau})) = N \left(\frac{\bar{t}}{\tau} + \ln \frac{\tau}{\bar{t}} - 1 \right)$$

- W tym wyrażeniu trudno jest rozpoznać asymptotyczną postać równania:

$$l(\lambda) - l(\tilde{\lambda}) = -\frac{1}{2} \frac{(\lambda - \tilde{\lambda})^2}{b^2} \Rightarrow L(\lambda) = k \exp \left(-\frac{(\lambda - \tilde{\lambda})^2}{2b^2} \right)$$

Przykład - wyznaczanie średniego czasu życia

- Czyli nie możemy od razu zastosować rozumowania, że wartość prawdziwa estymowanego mieści się w przedziale:

$$\tilde{\lambda} - \sigma(\tilde{\lambda}) < \lambda_0 < \tilde{\lambda} + \sigma(\tilde{\lambda})$$


z prawdopodobieństwem 68,3% (“1 sigma”)

- Możemy jednak zdefiniować wartości τ_+ oraz τ_- takie, że:

$$\tau_+ = \tilde{\tau} + \Delta_+ \quad \tau_- = \tilde{\tau} + \Delta_-$$

- Które spełniają warunek: $-(l(\tau_{\pm}) - l(\tilde{\tau})) = \frac{1}{2}$
- Wzór ten definiuje **niepewności niesymetryczne (asymetryczne)**
- W granicy $N \rightarrow \infty$ oczekiwalibyśmy: $\Delta_-, \Delta_+ \rightarrow u(\tilde{\tau}) = \sigma(\tilde{\tau})$
- Patrz rysunek na następnym slajdzie

Przykład - wyznaczanie średniego czasu życia



- Rysunek przedstawia funkcję:

$$-(l - l_{max}) = -(l(\tau) - l(\tilde{\tau}))$$
- Punkty τ_{+} , τ_{-} znajdują się na przecięciu z prostą:

$$-(l(\tau) - l(\tilde{\tau})) = 1/2$$
- Krzyżem jest zaznaczony punkt: $\tilde{\tau} = \bar{t}$
- Widzimy, że wraz ze zwiększaniem się N funkcja $-(l - l_{max}) = -(l(\tau) - l(\tilde{\tau}))$
- Coraz bardziej przybiera kształt symetrycznej paraboli a niepewności asymetryczne coraz mniej się różnią od siebie



Jednoczesna estymacja kilku parametrów

Jednoczesna estymacja kilku parametrów

- Jak już pamiętamy, w najogólniejszym przypadku mamy pewną ilość p parametrów $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_p)$, które chcemy estymować. Wtedy funkcja wiarygodności i równania wiarygodności:

$$L = \prod_{j=1}^N f(\mathbf{X}^{(j)}; \lambda) \quad l = \ln L = \sum_{j=1}^N \ln f(\mathbf{X}^{(j)}; \lambda) \quad \frac{\partial l}{\partial \lambda_i} = 0, \quad i = 1, 2, \dots, p$$

- Niestety, w przypadku wielu parametrów wszystko nam się komplikuje dodatkowo z uwagi na możliwe **korelacje pomiędzy parametrami**
- Analogicznie jak dla 1 parametru, rozwijamy funkcję wiarygodności:

$$L(\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(j)}; \lambda) = \sum_{j=1}^N \ln f(\mathbf{X}^{(j)}; \lambda)$$

na szereg Taylora wokół punktu: $\tilde{\lambda} = (\tilde{\lambda}_1, \tilde{\lambda}_2, \dots, \tilde{\lambda}_p)$

- Korzystając ze znikania 1-szych pochodnych dostajemy wtedy:

$$- (l(\lambda) - l(\tilde{\lambda})) = 1/2 (\lambda - \tilde{\lambda})^T A (\lambda - \tilde{\lambda}) + \dots$$

- Gdzie macierz A :

$$-A = \begin{pmatrix} \frac{\partial^2 l}{\partial \lambda_1^2} & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_2} & \cdots & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_2^2} & \cdots & \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_2} & \cdots & \frac{\partial^2 l}{\partial \lambda_p^2} \end{pmatrix}$$

Jednoczesna estymacja kilku parametrów

- W granicy $N \rightarrow \infty$ można zastąpić macierz A odpowiednimi wartościami oczekiwanymi $B = E(A)$
- Jeśli zaniedbamy wyrazy wyższych rzędów w rozwinięciu na szereg Taylora, dostaniemy wówczas funkcję wiarygodności postaci:

$$L = k \exp\left(-1/2(\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})^T B(\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})\right)$$

- Analogicznie jak dla jednego parametru, mamy tutaj p -wymiarowy rozkład normalny z macierzą kowariancji (dla estymatorów) $C = B^{-1}$
- Wariancje estymatorów największej wiarygodności $\tilde{\lambda}_1, \tilde{\lambda}_2, \dots, \tilde{\lambda}_p$ dane są przez elementy diagonalne macierzy C : $\sigma^2(\tilde{\lambda}_i) = c_{ii}$
- Elementy pozadiagonalne są kowariancjami poszczególnych par estymatorów: $\text{cov}(\tilde{\lambda}_j, \tilde{\lambda}_k) = c_{jk}$
- Możemy zdefiniować współczynnik korelacji między estymatorami:

$$\rho(\tilde{\lambda}_j, \tilde{\lambda}_k) = \frac{\text{cov}(\tilde{\lambda}_j, \tilde{\lambda}_k)}{\sigma(\tilde{\lambda}_j)\sigma(\tilde{\lambda}_k)}$$

Jednoczesna estymacja kilku parametrów

- Analogicznie jak w przypadku z jednym parametrem, niepewnością estymacji (typu A) będzie pierwiastek kwadratowy z wariancji estymatora: $u(\tilde{\lambda}_i) = \sigma(\tilde{\lambda}_i) = \sqrt{c_{ii}}$
- W przypadku 1D stwierdziliśmy, że za pomocą estymatora i jego niepewności możemy zdefiniować przedział obejmujący wartość prawdziwą estymowanego parametru z prawdopodobieństwem 68,3%. W przypadku wielowymiarowym przedział ten będzie określony również przez pełną macierz kowariancji (zależności między parametrami)
- Innymi słowy: obszar taki sprowadza się do elipsy kowariancji, analogicznej jak dla zmiennych losowych – czyli mamy **elipsy kowariancji dla estymowanych parametrów naszego rozkładu**
- Równanie elipsoidy kowariancji (p -wymiarowa przestrzeń):
$$g(\lambda) = 1 = 2 \{ l(\lambda) - l(\tilde{\lambda}) \} = (\lambda - \tilde{\lambda})^T B (\lambda - \tilde{\lambda})$$
- Dla $g(\lambda) = 1$ mamy obszar ufności z prawdopodobieństwem 68,3%

Metoda najw. wiar. a programy do analizy

7.1 The Fit Method

The Fit method is implemented in ROOT for the histogram classes `TH1`, the sparse histogram classes, `THnSparse`, the graph classes, `TGraph`, `TGraph2D` and `TMultiGraph` for fitting a collection of Graphs with the same function.

7.1.1 The TH1::Fit Method

To fit a histogram programmatically, you can use the `TH1::Fit` method. Here is the signatures of `TH1::Fit` and an explanation of the parameters:

```
TFitResultPtr Fit(TF1 *function, Option_t *option, Option_t *goption,  
                 Axis_t xmin, Axis_t xmax)
```

- `function` a pointer to the fitted function (the fit model) object. One can also use the function name. This name may be one of ROOT pre-defined function names or a user-defined function. See the next paragraph for the list of pre-defined functions.
- `*option`: The second parameter is the fitting option. Here is the list of fitting options:
 - “ `W` ” Set all weights to 1 for non empty bins; ignore error bars
 - “ `WW` ” Set all weights to 1 including empty bins; ignore error bars
 - “ `I` ” Use integral of function in bin instead of value at bin center
 - “ `L` ” Use log likelihood method (default is chi-square method). To be used when the histogram represents counts
 - “ `WL` ” Weighted log likelihood method. To be used when the histogram has been filled with weights different than 1.
 - “ `P` ” Use Pearson chi-square method, using expected errors instead of the observed one given by `TH1::GetBinError` (default case). The expected error is instead estimated from the the square-root of the bin function value.

Metoda najw. wiar. a programy do analizy

Example: Likelihood fit

- Use the pdf of observables and maximize the product of likelihoods.
 - In practice: minimize the $-2 \cdot \log$ of the likelihoods

Binned data

- Use Poisson pdf for bin content
- **Example:** data normally distributed

$$\mathcal{L} = \prod_{i=\text{bins}} \text{Poisson} \left[N_i^{\text{obs}}, A \exp \left(-\frac{1(x_i - \bar{x})^2}{2\sigma^2} \right) \right]$$

Unbinned data



- **Example:** normally distributed points about α

$$\mathcal{L} = \prod_{i=\text{measurements}} \frac{1}{\sqrt{2\pi}\sigma_i} \exp \left(-\frac{1(x_i - \alpha)^2}{2\sigma_i^2} \right)$$

$$-2 \ln \mathcal{L} = \sum_{i=\text{measurements}} \left[\frac{(x_i - \alpha)^2}{\sigma_i^2} + 2 \ln(\sqrt{2\pi}\sigma_i) \right]$$

- It looks familiar, doesn't it?

- 1σ uncertainty: increase of $-2 \ln \mathcal{L}$ by 1



Metoda najw. wiar. a programy do analizy

Simple fits

```
myh2->Fit("gaus", "", "", -2., 2.);
```



```
myh2->GetFunction("gaus")->Draw();
```

Retrieve a pointer to the fitted TF1

The pointer can be used to manipulate the function: plotting, changing style, inspecting parameters...

```
TFitResultPtr fitres = myh2->Fit("gaus", "S");
```

```
fitres->Parameter(2);
```

```
fitres->ParError(2);
```

```
fitres->Chi2();
```

```
fitres->Ndf();
```

- Some predefined fit functions available:
 - Exponential
 - Gaussian
 - Landau
 - Polynomial (up to 9th degree)
- Most common options:
 - "L" likelihood fit
 - "WL" likelihood fit with weighed points
 - "Q" quiet mode: do not print info on screen
 - "S" save the results in a TFitResultPtr object.





KONIEC